

時系列の状態空間モデル・時系列の機械学習

今日の目標

- 時系列モデルの状態空間モデルを説明できる
- 時系列予測ライブラリProphetが使える

状態空間モデル

時系列の隠れた変数

琵琶湖の漁の毎年の漁獲量は時系列. 過去の漁獲量(kg)のデータを見て, $AR(2)$ っぽい, とか, ϕ_1, ϕ_2, σ^2 はいくつ? とか推定することはできる. しか〜し.

- 実は背後に, 琵琶湖の生息するナマズの総数とか, モロコの総数とか, もっと言えば, 水温とか水草の量とか, 観測できないより本質的な時系列があるのでは?
 - 被食者捕食者の増減の話とかやったよね?/やります. 微分方程式, 数理モデル
- ホワイトノイズ ϵ_t っていうけど, 今年はたまたま稚魚が育たなかったっていうノイズと, 今年はコロナで漁船の整備ができなかった(?)っていうノイズは別なのでは?

システムと観測を分けて, もっと精密に考えたい!

状態空間モデル

状態空間モデルの簡単な場合

- 観測できない量
 - \mathbf{X}_t : 状態ベクトル(2次元)
 - \mathbf{v}_t : システムノイズベクトル(2次元)
 - w_t : 観測ノイズ(1次元)
 - \mathbf{v}_t, w_t は互いに独立なホワイトノイズ
- 観測できる量
 - Y_t : 観測値(1次元)
- 定数
 - F, G : 2×2 行列
 - H : 1×2 行列

$$\text{システムモデル } \mathbf{X}_t = F\mathbf{X}_{t-1} + G\mathbf{v}_t$$

$$\text{観測モデル } Y_t = H\mathbf{X}_t + w_t$$

状態空間 = \mathbf{X}_t の観測できない空間

状態ベクトルは, $\mathbf{X}_t = F\mathbf{X}_{t-1} + G\mathbf{v}_t = F(F\mathbf{X}_{t-2} + G\mathbf{v}_{t-1}) + G\mathbf{v}_t = \dots = F^t\mathbf{X}_0 + \sum_{t'=0}^{t-1} F^{t-t'}G\mathbf{v}_{t'}$ のように漸化式で計算される.

観測値 Y_t は漸化式で結ばれておらず, 各時刻ごとに $Y_t = H\mathbf{X}_t + w_t$ で \mathbf{X}_t から計算される.

例

例:琵琶湖の漁獲量

$$F = \begin{pmatrix} 1.01 & 0.3 \\ -0.5 & 0.98 \end{pmatrix}, \mathbf{X}_t = \begin{pmatrix} \text{なまずの個体数} \\ \text{モロコの個体数} \end{pmatrix}, G = \begin{pmatrix} 1 & 2 \\ 100 & 200 \end{pmatrix}, \mathbf{v}_t = \begin{pmatrix} \text{正規分布(水草の量)} \\ \text{正規分布(水温)} \end{pmatrix}$$

$$Y_t = \text{漁獲量(kg)}, H = \begin{pmatrix} 1000 & 10 \end{pmatrix}, \mathbf{X}_t = \begin{pmatrix} \text{なまずの個体数} \\ \text{モロコの個体数} \end{pmatrix}, w_t = \text{正規分布(漁船の数)}$$

例:AR(2)

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \epsilon_t.$$

は,

$$\begin{pmatrix} x_t \\ x_{t-1} \end{pmatrix} = \begin{pmatrix} \phi_1 & \phi_2 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} x_{t-1} \\ x_{t-2} \end{pmatrix} + \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} \text{正規分布} \\ \text{正規分布} \end{pmatrix},$$

$$y_t = \begin{pmatrix} 1 & 0 \end{pmatrix} \begin{pmatrix} x_t \\ x_{t-1} \end{pmatrix} + 0$$

と表せる.

AR(3)は

$$\begin{aligned} x_t &= \phi_1 x_{t-1} + \phi_2 x_{t-2} + \phi_3 x_{t-3} + \epsilon_t, \\ x_{t-1} &= 1 \cdot x_{t-1}, \\ x_{t-2} &= +1 \cdot x_{t-2}, \\ Y_t &= x_t + 0 \cdot \epsilon'_t \end{aligned}$$

のように3次元の状態空間で表せる.

例:ローカルレベルモデル

$$\begin{aligned} x_t &= x_{t-1} + \text{乱数}, \\ y_t &= x_t + \text{別の乱数} \end{aligned}$$

ランダムウォークだが, 観測者によるウォーカーの位置の測定値 y_t は正確ではない. その前提で, 正確な位置 x_t を求めたい.

状態空間モデルの特徴

- AR(m) や親戚の MA, ARMA, SARIMA などのモデルを統一的に表せる.
- これでないとなぜ表せないモデルもある.
- 制御工学でよく扱われて, 解法が整備されている. フィルタ, 平滑化. カルマンフィルタ [pykalman](#)
- パラメタが多い
- HMM=Hidden Markov model 隠れマルコフモデルはこの離散バージョン

状態空間モデルを使う手続き

1. 与えられた y_t を見る
2. (原理から考えて)モデルを書く
3. F, G, H が未知ならそれをパラメタ推定する

4. 与えられた学習データ $\{y_t\}_{t=0,\dots,T}$ から \mathbf{X}_t を状態推定(予測, フィルタ, 平滑化)する.
5. テストデータ y_t と, \mathbf{X}_t から求めた \hat{y}_t を比較して, 性能を評価する

Python の関数 [statsmodels.tsa.UnobservedComponents](#)

状態空間モデルの扱いやすい場合1

- $\mathbf{v}_t, \mathbf{w}_t$ が正規分布にしたがうと仮定する. このとき, 正規分布の加法性から, \mathbf{X}_t, Y_t などがすべて正規分布にしたがい, それらの母平均値, 母共分散の関係式をつかって解析できる.
- 制御工学でよく扱われて, 解法が整備されている. フィルタ, 平滑化. カルマンフィルタ [pykalman](#)

状態空間モデルの扱いやすい場合2:隠れマルコフモデル

- 「 \mathbf{X}_t が離散型確率変数の場合」を考えたい. $X_t = 1, 2, \dots, n$.
- システムモデルは「 \mathbf{X}_t が確率的に時間発展する」ことを表すので, マルコフ連鎖で書くのが自然. M は推移確率行列. 計算科学B, 確率モデル及び実習

$$\begin{aligned} P(X_t = 1) &= M_{11}P(X_{t-1} = 1) + M_{12}P(X_{t-1} = 2) + \dots + M_{1n}P(X_{t-1} = n) \\ P(X_t = 2) &= M_{21}P(X_{t-1} = 1) + M_{22}P(X_{t-1} = 2) + \dots + M_{2n}P(X_{t-1} = n) \\ &\vdots \\ P(X_t = n) &= M_{n1}P(X_{t-1} = 1) + M_{n2}P(X_{t-1} = 2) + \dots + M_{nn}P(X_{t-1} = n) \end{aligned}$$

- 観測できない(隠れた) $X = 1, 2, \dots, n$ という状態があり, ある法則で時間発展する. 観測される Y_t の値は X から決まる.

時系列の機械学習

因果関係, ある時点以前のデータから以降のデータを予測することの需要が大きい, ことから次のように行われる

1. 観測データ x_t を前半の $x_{\text{train}t}$ と, 後半の $x_{\text{test}t}$ とに分ける
2. $x_{\text{train}t}$ から, モデル, パラメタを推定する.
 - 誤差最小や尤度最大, などの原理がありうるが, パラメタの個数を変える変更(例AR(m)の m の変更)の際は, AIC, BICなどの情報量規準で考えることになる.
3. 推定したモデル, パラメタから, \hat{x}_t を作る.
4. \hat{x}_t と $x_{\text{train}t}$ との誤差を確認する. [statsmodelsでは predict() で求められることが多い. fittedvalues という名前になっていることがある] 初項から何個かは \hat{x}_t が作れないことがある.
5. \hat{x}_t と $x_{\text{test}t}$ との誤差を確認する. [statsmodelsでは predict() で求められることが多い.]

ライブラリ pmdarima

SARIMA(p,d,q,P,D,Q,m)用の関数. statsmodels の ar_model や arma_model とはまた別のフレーバー.

Notebook参照

ライブラリ Prophet

日ごとのデータを扱う ライブラリ. Facebook が開発するオープンソース. 祝日のデータなども総動員して自動化されている.

Notebook参照

その他の時系列の機械学習

- RNN=Recurrent Neural Network, LSTM
 - 自然言語は, 順番がついた文字や単語の列であることから, 時系列解析と共通点がある
-